

文章编号:1674-7607(2025)05-0733-05

DOI:10.19805/j.cnki.jcspe.2025.250019

基于长短期记忆网络的电力市场价格预测研究

邵云姝¹, 张琳², 周乃康², 陈晓利³, 王菲²

(1. 大韩民国高丽大学, 首尔 02841; 2. 国家电投集团电站运营技术(北京)有限公司, 北京 102200;
3. 国家电投集团东北电力有限公司, 辽宁沈阳 110181)

摘要: 考虑电力市场多因素耦合对电力价格预测的影响, 建立了基于长短期记忆(LSTM)神经网络的电力市场价格预测模型。设置历史新能源出力、外送电量、电力负荷等影响电力供需关系的边界因素作为 LSTM 学习参数, 并进行数据预处理; 优化 LSTM 神经网络的层数、迭代次数、学习率等模型参数, 生成电价预测模型, 得到交易日的电价预测曲线。通过算例仿真验证方法的正确性, 构建某现货省份电力交易的预测场景, 引入电价预测准确率评估指标。结果表明: 该方法为日前出清电价预测研究提供参考, 可为电力市场交易主体提供有效的竞价策略, 并获取可观的电力营销收入。

关键词: 电力市场; LSTM 神经网络; 日前现货电价; 电价预测模型

中图分类号: TK01 **文献标志码:** A **学科分类号:** 120.30

Research on Price Prediction of Electricity Market Based on Long-Short Term Memory Network

SHAO Yunshu¹, ZHANG Lin², ZHOU Naikang², CHEN Xiaoli³, WANG Fei²

(1. Korea University, Seoul 02841, South Korea; 2. SPIC Station Operation Technology Co., Ltd., Beijing 102200, China; 3. SPIC Northeast Electric Power Co., Ltd., Shenyang 110181, Liaoning Province, China)

Abstract: Considering the impact of multi-factor coupling in the power market on power price forecasting, a power market price forecasting model based on long-short term memory (LSTM) neural network was established. The historical new energy output, power transmission, power load and other factors affecting the power supply and demand relationship were set as the boundary factors of LSTM learning parameters, and data preprocessing was carried out. The model parameters of LSTM neural network, including the number of layers, iteration times and learning rate, were optimized to generate a training model for electricity price forecasting, which was then used to forecast the electricity price curves for trading days. The correctness of the proposed method was verified through example simulation, a prediction scenario for electricity trading in a spot market province was constructed, and the evaluation indicators of power price forecasting accuracy were introduced. The results indicate that this method provides a reference for research on day-ahead clearing price prediction and offers market participants in the electricity market effective bidding strategies to achieve substantial marketing revenue.

Key words: electricity market; LSTM neural network; current spot electricity price; electricity price prediction model

收稿日期:2025-01-07 修订日期:2025-01-15

作者简介:邵云姝(1996—),女,黑龙江讷河人,博士研究生,研究方向为电力市场交易、碳交易等,E-mail:cristalshao@0521korea.ac.kr。

在当今全球能源结构转型和电力市场自由化的背景下,电力价格预测对于市场参与者尤为关键。准确的电价预测不仅能够帮助电力公司和交易者优化调整发电计划和执行有效的竞价策略,降低经营风险,还能为政策制定者提供市场调控的决策支持。

然而,可再生能源在电力系统中的占比日益增加,导致发电不稳定性加剧,使得电价预测的难度增加。此外,电价的波动性受到多种因素的影响,包括供需关系、天气变化、政策调整以及市场参与者的行为等,这些因素的复杂交互使得电力市场多因素耦合下的电价预测成为一个极具挑战性的任务。

近年来,人工智能算法在电价预测领域取得了巨大进步。文献[1]选择循环神经网络(RNN)的方式,尽管能解决 BP 神经网络与时序数据无法有效连接的问题,但是 RNN 内 tanh 函数大多呈现 1 和 -1 的趋势。在采用 BP 神经网络预测电价方面,文献[2]第一次从人工神经网络领域进行电价预测分析。文献[3]提出一种基于变分模态分解(VMD)和改进粒子群算法(PSO)优化最小二乘支持向量机(LSSVM)的短期电价预测模型,通过改进的 PSO 优化 LSSVM 模型的参数,获得电价预测值。

文献[4]采集出电力市场日前电价数据,利用长短期记忆(LSTM)神经网络处理这些数据,构建电力市场日前电价预测模型,实现电力市场日前电价预测。文献[5]提出了基于 LSTM 神经网络和极限梯度提升(XGBoost)的组合预测模型,该组合模型有效提升了短期电价的预测精度,且具有很强的普适性,可应用于电力市场短期电价预测。文献[6]提出了一种基于经验模式分解(EMD)与 LSTM 神经网络的序列电价预测模型,使用 EMD 提取电价序列中的周期分量与趋势分量,利用 LSTM 神经网络分别对周期分量与趋势分量进行序列预测,输出各分量的预测结果,通过支持向量机回归(SVR)叠加各分量的预测序列生成预测价格序列。然而,上述 3 种方法只考虑了历史现货出清电价的影响,未考虑市场的物理边界对电价的冲击因素。

本研究提供了一种探索电力市场多因素耦合对电力价格预测影响的方法,充分考虑了新能源出力、省间联络线、电力负荷、非市场化出力等因素,并应用 LSTM 深度神经网络结合特征选择算法进行电力价格预测。

1 电价形成机制与相关因素分析

1.1 电价形成机制

为进一步发挥市场在资源配置中的决定性作用,更好地反映电力商品的时间、空间价值,应构建

合理的电价形成机制。

以社会福利最大或发电成本最低为目标,以电力平衡、机组出力上下限、输电线路容量限制为约束,构建出清模型。优化目标要求优先出清发电边际成本低的发电机组,不同机组边际成本典型排序(无政策干预时)如图 1 所示。电力市场中,交易出清模型如图 2 所示。




图 1 不同机组边际成本排序

Fig. 1 The ranking of marginal costs for different units



图 2 出清模型

Fig. 2 Clearing model

1.2 电价主要相关影响因素

(1) 供需关系动态变化

电力供给主要受发电能力、燃料供应、设备维护等因素影响,而电力需求则与经济发展、天气变化、用户行为等因素密切相关。当电力供给大于需求时,电价往往趋于下降;反之,当电力需求超过供给时,电价则会上升。

供求关系对电价的影响机制主要体现在:供求关系决定了电力的边际成本,进而影响电价水平。此外,供求关系还会影响电力市场的竞争程度,进而影响电价形成机制。

(2) 可再生能源渗透率

统一出清电价由满足系统负荷需求的最后一台边际机组报价决定。

当可再生能源发电量增加时,传统机组的发电空间被压缩。结合图 1、图 2 可知,当风光出力增加时,系统总供给曲线右移,传统高成本机组被挤出调度序列,出清电价由更低成本的机组决定。

假设某时段风电出力从 100 MW 突增至 300 MW,导致火电机组调度量减少。边际机组从燃气机组(报价 500 元/(MW·h))切换至燃煤机组(报价 300 元/(MW·h)),出清电价下降 40%。

2 基于 LSTM 神经网络的电价预测模型

2.1 LSTM 神经网络

在标准的 RNN 中,该重复模块将具有非常简单的结构,标准的 RNN 网络如图 3 所示,其中 A 表示 LSTM 的模块。




图 3 标准 RNN 结构模型

Fig. 3 Standard RNN structural model

传统的 RNN 会出现梯度消失和梯度爆炸问题,LSTM 神经网络作为一种特殊的 RNN,能够很好地解决此类问题^[7]。LSTM 神经网络具有良好的记忆能力,学习时间序列的长短期依赖于信息,适合处理和预测时间序列中的间隔和延迟事件^[8]。LSTM 神经网络的这些优势是通过对神经元增加“门”信息来实现的,其具体结构如图 4 所示。




图 4 LSTM 神经网络结构模型

Fig. 4 Structural model of LSTM neural network

与传统的 RNN 相比,LSTM 神经网络的基本神经元新增 4 个门来控制信息状态,分别为忘记门、输入门、更新门和输出门。

首先,LSTM 神经网络通过忘记门忘记部分信息,忘记程度由 σ 单元决定, σ 单元输出是 $[0, 1]$ 内的变量,代表不同程度的信息能够流过,0 表示都不能通过,1 表示都能通过;其次,通过输入门判断更新哪些信息及内容,再利用 tanh 层得到新的候选信息,从而被更新到特征信息中;然后,通过忘记门和输入门对数据状态进行合并,从而整合历史信息与更新信息;最后,通过历史数据、特征值数据信息确定输出信息的特征状态,再通过输出门的 σ 单元及

tanh 层,最终得到 LSTM 神经网络单元的输出。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (1)$$

$$\tilde{C} = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C} \quad (3)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (5)$$

式中: $\sigma(x) = \frac{1}{1+e^{-x}}$,为 S 型激活函数; x_t, h_{t-1} 分别为本单元的输入和上一单元的输出; W_i, W_o, W_C 分别为相应门与上个单元输出 h_{t-1} 和当前时刻输入 x_t 相乘得到的矩阵权重; b_C, b_i, b_o 为偏置项;tanh 为激活函数; C_t, \tilde{C} 分别为上一状态值、新状态值; f_t, i_t, o_t, h_t 分别为遗忘门、输入门、输出门的值和输出值。

2.2 数据预处理

为保证输入数据的质量,需要对原始数据进行预处理。电价预测影响因素原始数据存在数据缺失、异常或不一致时,会影响数据分析和模型训练的结果,从而影响分析的准确性。因此,通过数据清洗确保数据的准确性和一致性,提高 LSTM 模型对电价预测的准确率。

对于缺失值的处理,本文采用均值法,通过相似度最大的 3 天同时段的均值获得,计算公式为

$$P(i, t) = (P(j, t) + P(k, t) + P(m, t))/3 \quad (6)$$

式中: $P(i, t)$ 为确实日 i 日 t 时段的电价; $P(j, t), P(k, t), P(m, t)$ 分别为相似日 j, k, m 日 t 时段的电价。

对于异常值的处理,本文采用箱线图识别异常值,然后采用相似日均值修正异常值。

$$P(i, t) < Q_1(i, t) - 1.5 \times D(i, t) \text{ 或者 } P(i, t) < P_{t\text{下}} \text{ 限},$$

$$P(i, t) > Q_3(i, t) + 1.5 \times D(i, t) \text{ 或者 } P(i, t) > P_{t\text{上}} \text{ 限},$$

那么 $P(i, t)$ 采用式(6)进行优化。其中: $Q_1(i, t), Q_3(i, t)$ 分别为数据源 t 时段 25%、75% 的数据点小于或等于这个值; $I(i, t)$ 为 $Q_3(i, t)$ 与 $Q_1(i, t)$ 的差值; $P_{t\text{上}} \text{ 限}, P_{t\text{下}} \text{ 限}$ 分别为电力市场中 t 时段的价格上、下限。

对于数据标准化和归一化的处理,采用 min-max 归一法,计算公式如下:

$$X^* = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (7)$$

式中: X^* 为归一化后的值; x_{\max}, x_{\min} 分别为数据源中的最大值、最小值; x 为原始数据。

2.3 基于 LSTM 神经网络的电价预测模型

LSTM 神经网络包括五部分,即输入向量、LSTM 隐藏层、Relu 激活层、全连接层和输出预测值。输入向量从输入层进入到 LSTM 隐藏层,经过

LSTM 隐藏层的训练,训练后的向量输出到 Relu 激活层进行非线性变换,以便神经网络能够学习到更复杂的特征表示和决策边界。然后,经过全连接层的训练后得到最终结果的预测值,进而输出预测值。

在输入向量中,考虑新能源、联络线外送、电力负荷等因素,选取以下特征因子作为输入特征,具体如表 1 所示。

表 1 特征因子表

Tab. 1 Feature factor table

序号	特征因子	特征描述
1	P_W	风电出力曲线
2	P_S	光伏出力曲线
3	P_L	联络线负荷曲线
4	P_P	电力负荷曲线

3 算例分析

3.1 评价指标

为了评估电价预测模型的准确性,引入评估指标,即预测值与真实值的偏离程度。

预测评价指标采用平均绝对百分比误差 (R_{MAPE}) 和均方根误差 (R_{RMSE}), 公式如下:

$$R_{MAPE} = \frac{1}{n} \sum_{N=0}^n \left| \frac{(y_N - \hat{y}_N)}{y_N} \right| \quad (8)$$

$$R_{RMSE} = \frac{1}{n} \sqrt{\sum_{N=0}^n (y_N - \hat{y}_N)^2} \quad (9)$$

式中: y_N 、 \hat{y}_N 分别为第 N 个预测电价数据的真实值和预测值; n 为样本个数。

3.2 预测模型

我国某省份电力现货市场采用边际电价定价,每 15 min 一个时段,一天 96 个时段。以 8 月份 31 天数据作为数据源,采用 MATLAB 软件进行仿真分析。

输入变量 x 序列长度为 2 880 时段(即 30 天 × 96 时段),特征因子矩阵维度为 2 880 × 4,影响因子分别为风电出力、光伏出力、联络线负荷、负荷预测值。按照该方式对原始数据进行变换,生成样本集,并进行归一化处理。

为了训练和优化模型,LSTM 神经网络层数采用 2~6 层,最大迭代次数为 1 000。损失函数使用均方根误差 R_{RMSE} ,优化算法为 Adam。预测模型的指标如表 2 所示。

从表 2 可以看出,LSTM 神经网络层数越多, R_{MAPE} 准确率越高, R_{RMSE} 越小,网络优化模型的精度

越来越高。网络层数为 2 时, R_{MAPE} 准确率较低,如图 5 所示。网络层数为 3 时,在多次模拟过程中,网络不稳定, R_{RMSE} 及 R_{MAPE} 评价指标在网络层数 2、4 之间徘徊。从表 2 可以看出:LSTM 网络层数为 3 时,评价指标出现 2 种跳变情况,分别与网络层数为 2、4 时指标数值水平持平。网络层数为 4 时,网络优化模型稳定,且随着层数递增, R_{RMSE} 及 R_{MAPE} 指标优化效果递减,如图 6 所示。因此,在训练时综合考虑模拟时效性及模拟效果,选择网络层数为 4。

表 2 预测模型网络优化指标

Tab. 2 Optimization indicators of prediction model network

LSTM 网络层数	迭代次数	R_{RMSE}	精确度/%
2	1 000	97.842 0	65.84
3	1 000	68.176 6/29.510 5	70.12/87.53
4	1 000	29.551 8	87.61
5	1 000	29.547 6	87.67
6	1 000	27.673 4	87.73




图 5 网络层数为 2 时的训练模型预测结果

Fig. 5 Results predicted by the train model with two network layers




图 6 网络层数为 4 时的训练模型预测结果

Fig. 6 Results predicted by the train model with four network layers

3.3 真实场景电价预测结果

LSTM 神经网络层数设置为 4,输入数据由 2 880 时段延伸到年累计 1—8 月份 23 328 时段(即 243 天 × 96 时段)数据,并且考虑各时段特征因子(风电出力、光伏出力、联络线外送及负荷)对电价的影响。通过仿真,数据源基于 2 880 时段(短周期历史数据)和 23 328 时段(长周期历史数据),分别训练学习模型,并进行日前电价曲线预测,结果如图 7、图 8 所示。2 个数据源的预测结果评价指标如表 3 所示。




图 7 2 880 时段数据源预测结果

Fig. 7 Prediction results of 2 880 data source




图 8 23 328 时段数据源预测结果

Fig. 8 Prediction results of 23 328 data source

表 3 预测结果评价指标

Tab. 3 Evaluation indicators for prediction results

数据源数量	R_{RMSE}	$R_{MAPE}/\%$
2 880	28.619 7	87.63
23 328	48.503 1	80.72

由表 3 可以看出:仅采用 8 月份的数据源(短周期历史数据)时预测准确率为 87.63%,满足电力交易业务需求;数据源大量增加反而降低了预测的准确率。这说明日前现货电价与近期的影响因子相关性更大。同时,当电价在 100 元/(MW·h)及以上时,训练的模型稳定,电价预测值与实际值贴合程度更高。当电价处于较低值时,电价预测值与实际值的偏差稍大,原因为电价受近期的市场情绪、电网运行限制等不易量化的因素影响,在后续阶段可研究引入。

4 结论

本文提出了一种探索电力市场多因素耦合对电力价格预测影响的方法,充分考虑新能源出力、外送电量、电力负荷等耦合因素,建立了基于长短期记忆神经网络的电力市场价格预测模型,通过算例仿真验证了模型的有效性和电价预测的准确率,结果表明日前现货电价与近期影响因子的相关性更大。

参考文献:

[1] 邹政达,孙雅明,张智晟. 基于蚁群优化算法递归神经

网络的短期负荷预测[J]. 电网技术, 2005, 29(3): 59-63.

ZOU Zhengda, SUN Yaming, ZHANG Zhisheng. Short-term load forecasting based on recurrent neural network using ant colony optimization algorithm[J]. **Power Grid Technology**, 2005, 29(3):59-63.

[2] SZKUTA R B, SANABRIA A L. Electricity price short-term forecasting using artificial neural networks [J]. **IEEE Transactions on Power Systems**, 1999, 14(3):851-857.

[3] 杨昭,张钢,赵俊杰,等. 基于变分模态分解和改进粒子群算法优化最小二乘支持向量机的短期电价预测[J]. **电气技术**, 2021, 22(10):11-16.

YANG Zhao, ZHANG Gang, ZHAO Junjie, et al. Optimization of short term electricity price prediction using least squares support vector machine based on variational mode decomposition and improved particle swarm optimization algorithm[J]. **Electrical Technology**, 2021, 22(10):11-16.

[4] 侯丙辛. 基于 LSTM 神经网络的电力市场日前电价预测研究[J]. **电气技术与经济**, 2022(5):40-42.

HOU Bingxin. Research on daily electricity price prediction in electricity market based on LSTM neural network[J]. **Electrical Equipment and Economy**, 2022(5):40-42.

[5] 郑宏,刘立群. 基于 LAST 与 XGBoot 组合模型电价预测[J]. **太原科技大学学报**, 2023, 44(2):131-136.

ZHENG Hong, LIU Liqun. Electricity price prediction based on the combination model of LAST and XG-Boot[J]. **Journal of Taiyuan University of Science and Technology**, 2023, 44(2):131-136.

[6] 勾玄,肖先勇. 基于经验模式分解与 LSTM 神经网络的短期电价预测模型[J]. **西安理工大学学报**, 2020, 36(1):129-134.

GOU Xuan, XIAO Xianyong. Short term electricity price prediction model based on empirical mode decomposition and LSTM neural network[J]. **Journal of Xian University of Technology**, 2020, 36(1):129-134.

[7] ABDEL-NASSER M, MAHMOUD K. Accurate photovoltaic power forecasting models using deep LSTM-RNN[J]. **Neural Computing & Applications**, 2017(10): 1-14.

[8] 付文博,孙涛,梁藉. 深度学习原理及应用综述[J]. **计算机科学**, 2018, 45(6A):11-15.

FU Wenbo, SUN Tao, LIANG Ji. Overview of deep learning principles and applications[J]. **Computer Science**, 2018, 45(6A):11-15.